

Klasifikasi Teks Mitos dan Fakta Kesehatan Menggunakan Algoritma *Random Forest* dengan Optimasi *Class Weight*

^{1*}Rizky Ananda Putra, ²Risky Aswi Ramadhani, ³Julian Sahertian

^{1,2,3}Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: ¹rizkyannandsan@gmail.com, ²risky_aswi@unpkediri.ac.id,

³juliansahertian@unpkediri.ac.id

Penulis Korespondens : Rizky Ananda Putra

Abstrak—Penyebaran misinformasi kesehatan di ruang digital dapat membangun persepsi ancaman yang keliru pada masyarakat, sehingga diperlukan metode klasifikasi teks. Penelitian ini mengklasifikasikan 200 data teks kesehatan ke dalam kelas mitos 52 data dan fakta 148 data menggunakan algoritma *Random Forest*. *Dataset* yang digunakan telah divalidasi oleh pakar medis. Alur penelitian meliputi prapemrosesan teks, ekstraksi fitur TF-IDF, serta pelatihan dan pengujian model dengan berbagai rasio data. Optimasi dilakukan menggunakan parameter *class_weight* untuk mengatasi ketidakseimbangan data. Hasil pengujian menunjukkan dengan rasio 90:10 mendapat nilai akurasi keseluruhan sebesar 85,00%, dengan *f1-score* kelas fakta sebesar 0.9032 dan kelas mitos sebesar 0.6667. Kontribusi penelitian ini adalah pembuktian bahwa parameter *class_weight* mampu menjaga performa klasifikasi kelas minoritas tetap berada di atas ambang batas tebakan acak 0,5000. Hasil ini dapat menjadi referensi pemodelan klasifikasi hoaks kesehatan ke depan.

Kata Kunci—Klasifikasi Teks, Random Forest, Class Weight, TF-IDF, Informasi Kesehatan

Abstract—The spread of health misinformation in the digital space can create a false sense of threat among the public, making text classification methods necessary. This study classified 200 health-related text data points into 52 'myth' and 148 'fact' categories using the Random Forest algorithm. The dataset used has been validated by medical experts. The research workflow includes text pre-processing, TF-IDF feature extraction, and model training and testing with various data ratios. Optimisation was performed using the *class_weight* parameter to address data imbalance. Testing results show that with a 90:10 ratio, the overall accuracy was 85.00%, with an F1-score of 0.9032 for the fact class and 0.6667 for the myth class. The contribution of this research is the demonstration that the *class_weight* parameter is capable of maintaining the classification performance of the minority class above the random guessing threshold of 0.5000. These results can serve as a reference for future health hoax classification modelling.

Keywords—Text Classification, Random Forest, Class Weight, TF-IDF, Health Information

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Media digital saat ini memudahkan masyarakat dalam mencari informasi kesehatan secara mandiri melalui media sosial ataupun mesin pencari [1], [2]. Kebiasaan ini sering kali dianggap lebih efisien dan murah dibandingkan harus langsung pergi ke klinik atau rumah sakit

[3]. Namun, informasi kesehatan yang beredar di internet tidak selalu valid karena siapa saja bisa menulis dan membagikannya tanpa pengawasan dari tenaga medis [4]. Jika masyarakat langsung memercayai dan mengikuti informasi yang salah tersebut untuk pengobatan mandiri, hal ini berisiko membangun persepsi kesehatan yang keliru di lingkungan sosial masyarakat [5]. Salah satu bentuk informasi salah yang sering dipercaya masyarakat adalah mitos kesehatan, yaitu klaim medis yang tidak terbukti benar secara klinis tetapi sudah terlanjur beredar luas [6]. Dari sudut pandang komputasi, diperlukan sebuah model yang mampu mengenali perbedaan pola kalimat antara mitos dan fakta. Untuk mencapai hal tersebut, pemilihan algoritma klasifikasi teks memegang peranan penting dalam menentukan performa akhir model yang dikembangkan [7].


Pengembangan model klasifikasi teks hoaks dan informasi kesehatan telah banyak dibahas dalam penelitian sebelumnya dengan memanfaatkan berbagai algoritma. Sebagai contoh, penelitian berbasis *Support Vector Machine* (SVM) yang dilakukan oleh Ropikoh dkk. menghasilkan akurasi sebesar 92,20% [8]. Di sisi lain, algoritma *Naive Bayes Classifier* yang diterapkan oleh Roshinta dkk. dalam mendeteksi hoaks kesehatan berhasil memperoleh akurasi sebesar 90,9% [9]. Sementara itu, Hendriyanto dan Sari memanfaatkan algoritma *K-Nearest Neighbor* (KNN) dan menghasilkan akurasi sebesar 93,33% [10], disusul oleh penelitian Shalih dan Tju yang menggunakan algoritma *Decision Tree* dengan capaian akurasi sebesar 93,5% [11]. Selain itu pada studi yang dilakukan oleh Setyadin dkk. membuktikan bahwa algoritma *Random Forest* mampu menghasilkan performa yang cukup baik dengan akurasi tertinggi sebesar 98,9% saat menangani deteksi berita palsu [12].

Meskipun beberapa algoritma di atas memiliki tingkat akurasi yang cukup tinggi, beberapa penelitian tersebut masih menggunakan data yang tidak seimbang. Pada beberapa kasus, data teks kesehatan asli di lapangan sering kali mengalami masalah (*imbalanced data*) [13]. Jika data yang tidak seimbang ini langsung dimasukkan ke dalam model klasifikasi tanpa penanganan, model akan cenderung berpihak pada kelas yang jumlahnya mayoritas sehingga gagal mengenali teks mitos dengan baik. Selain itu, belum banyak penelitian yang secara khusus menguji performa *Random Forest* untuk membedakan karakteristik teks fakta dan mitos kesehatan dalam bahasa Indonesia pada kondisi data yang tidak seimbang.

Oleh karena itu, penelitian ini berfokus pada klasifikasi teks mitos dan fakta kesehatan menggunakan algoritma *Random Forest*. Secara garis besar, alur penelitian ini dimulai dari tahap pengumpulan dan validasi data, prapemrosesan teks, ekstraksi fitur TF-IDF, hingga proses pelatihan, pengujian, dan evaluasi performa model klasifikasi. Letak kebaharuan dari penelitian ini adalah penerapan model *Random Forest* yang dioptimalkan dengan parameter *class weight* untuk mengatasi masalah ketidakseimbangan. *Dataset* dalam penelitian ini juga menggunakan data yang kebenaran labelnya divalidasi langsung oleh pakar medis. Kontribusi dari penelitian ini adalah memberikan pembuktian mengenai efektivitas parameter *class weight* dalam performa klasifikasi kelas minoritas dengan data yang tidak seimbang. Analisis performa komparatif melalui evaluasi metrik akurasi, presisi, *recall*, dan *f1-score* ini diharapkan dapat menjadi referensi dalam pengembangan sistem klasifikasi hoaks kesehatan ke depannya.

II. METODE

Tahapan dan prosedur yang dilakukan dalam penelitian ini disajikan pada Gambar 1 di bawah.



Gambar 1. Alur Penelitian

Berdasarkan Gambar 1 di atas, rincian dari masing-masing tahapan diuraikan sebagai berikut:

1. Pengumpulan dan Validasi Label Data

Data dikumpulkan menggunakan kurasi manual dari berbagai platform kesehatan di Indonesia, seperti Alodokter, Halodoc, HelloSehat, dan situs web medis resmi lainnya. Teks berisi satu hingga dua kalimat yang memuat klaim mitos atau fakta disalin secara verbatim ke dalam perangkat lunak *Microsoft Excel*. Setelah data terkumpul, dilakukan pemberian label awal untuk memisahkan teks ke dalam dua kategori, yaitu kelas Fakta dan kelas Mitos. Untuk memastikan kebenaran informasi, seluruh data teks beserta label tersebut divalidasi langsung oleh dokter umum selaku pakar medis.

2. Text Preprocessing

Berdasarkan prinsip dasar *Natural Language Processing*, mesin komputasi membutuhkan prapemrosesan teks yang terstruktur [14]. Proses prapemrosesan dilakukan untuk mengubah data teks mentah menjadi teks bersih yang dapat diolah oleh komputer. Tahapan yang diterapkan meliputi:

- Case Folding*, yaitu mengubah seluruh huruf dalam teks menjadi huruf kecil (*lowercase*).
- Cleaning Symbol*, yaitu menghapus karakter angka, simbol tanda baca, serta tautan URL internet.
- Tokenization*, yaitu memecah kalimat utuh menjadi kumpulan kata tunggal berdasarkan spasi.
- Stopwords Removal*, yaitu membuang kata-kata umum yang tidak membawa informasi penting (seperti kata hubung "dan", "di", "yang") menggunakan daftar *stopword* standar bahasa Indonesia.

- e. *Stemming*, yaitu mengubah kata yang berimbuhan menjadi bentuk kata dasarnya (misalnya kata "menyebabkan" menjadi "sebab") dengan memanfaatkan pustaka *Sastrawi*.

3. Ekstraksi Fitur TF-IDF

Teks bersih hasil prapemrosesan selanjutnya dikonversi menjadi bentuk angka menggunakan metode TF-IDF [15]. Metode ini menghitung bobot kepentingan sebuah kata berdasarkan kemunculannya dalam suatu dokumen dan kelangkaannya di seluruh dokumen korpus. Rumus untuk TF-IDF dapat dilihat pada Persamaan 1, 2, dan 3.

- a. *Term Frequency* (TF)

$$TF = \frac{\text{Jumlah Kemunculan Kata}}{\text{Jumlah Kata pada Dokumen}} \quad (1)$$

- b. *Inverse Document Frequence* (IDF)

$$IDF = \log \frac{\text{Jumlah Dokumen}}{\text{Jumlah Suatu Kata Muncul}} \quad (2)$$

- c. Bobot Akhir TF-IDF

$$TF - IDF = TF \times IDF \quad (3)$$

4. Pemodelan dan Pengujian

Fitur berupa angka bobot dari TF-IDF kemudian dimasukkan ke dalam algoritma *Random Forest* untuk proses klasifikasi. *Random Forest* bekerja dengan cara membangun kumpulan pohon keputusan (*Decision Trees*) secara acak (N) dari sampel data latih melalui metode *bagging* atau *bootstrap aggregating*. Dalam pembentukan setiap pohon keputusan, penentuan pemisahan cabang (*splitting node*) didasarkan pada nilai kriteria *Gini Impurity* untuk mengukur tingkat keheterogenan data pada sub-set fitur kata yang dipilih [16]. Rumus untuk menghitung *Gini Impurity* (G) pada sebuah simpul (*node*) dapat dilihat pada Persamaan 4.

$$G = 1 - \sum_{i=1}^C (p_i)^2 \quad (4)$$

Di mana C adalah jumlah total kelas (dalam penelitian ini $C = 2$, yaitu kelas Mitos dan Fakta), dan p_i merupakan probabilitas kemunculan data dari kelas i pada simpul tersebut.

Untuk mengoptimalkan kinerja algoritma pada *dataset* kesehatan ini yang mungkin tidak seimbang, penelitian ini mengintegrasikan strategi *Cost-Sensitive Learning* langsung ke dalam proses pemodelan menggunakan parameter pembobotan kelas (*class_weight='balanced'*). Parameter ini secara otomatis akan menyesuaikan bobot penalti kesalahan pada pohon keputusan secara terbalik dengan frekuensi kelas pada data latih [17], rumusnya dapat dilihat pada Persamaan 5.

$$\text{Bobot Kelas} = \frac{\text{Total Jumlah Data}}{\text{Jumlah Kelas} \times \text{Jumlah Data per Kelas}} \quad (5)$$

Melalui rumus ini, kelas Mitos yang jumlahnya sedikit akan diberikan bobot penalti yang lebih besar agar model tidak bias ke kelas Fakta. Pada tahap pengujian, setiap individu pohon keputusan ($T_1, T_2, \dots, T_N$) akan mengeluarkan prediksi label kelasnya masing-masing secara independen. Keputusan akhir untuk menentukan apakah suatu teks kesehatan termasuk

ke dalam kelas Mitos atau Fakta diambil berdasarkan hasil voting terbanyak. Persamaan matematis untuk penentuan kelas akhir $\hat{y}$ dapat dirumuskan pada Persamaan 6.

$$\hat{y} = \text{mode}\{T_1(x), T_2(x), \dots, T_N(x)\} \quad (6)$$

Di mana mode adalah fungsi statistik untuk mengambil nilai atau label kelas yang paling sering muncul (mayoritas) dari seluruh prediksi pohon keputusan. Proses pengujian nantinya dilakukan dengan membagi *dataset* menggunakan teknik *Split Validation* dari 50:50 hingga 90:10.

5. Evaluasi Performa

Untuk mengukur performa model *Random Forest* dalam mengklasifikasikan teks, hasil pengujian dievaluasi menggunakan teknik *Confusion Matrix*. Matriks ini membandingkan kesesuaian antara Label Aktual dengan Label Prediksi melalui empat indikator, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN) [18]. Hubungan antara label aktual dan hasil prediksi sistem disajikan pada Gambar 2.

		DATA PREDIKSI	
DATA AKTUAL	TP (True Positive)	FP (False Positive)	
	FN (False Negative)	TN (True Negative)	

Gambar 2. *Confusion Matrix*

Berdasarkan nilai dari keempat indikator yang terbentuk pada Gambar 2 di atas, performa klasifikasi dihitung secara matematis menggunakan empat metrik evaluasi pada Persamaan 7, 8, 9, dan 10.

a. Accuracy

$$\text{Accuracy} = \frac{TP+TN}{TP+FP+TN+FN} \quad (7)$$

b. Precision

$$\text{Precision} = \frac{TP}{TP+FP} \quad (8)$$

c. Recall

$$\text{Recall} = \frac{TP}{TP+FN} \quad (9)$$

d. F1-Score

$$F1 - \text{Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (10)$$

III. HASIL DAN PEMBAHASAN

1. Pengumpulan dan Validasi Label Data

Proses pengumpulan data menghasilkan total 200 teks kesehatan berbahasa Indonesia yang diambil secara manual dari platform Alodokter, Halodoc, HelloSehat, dan situs web medis resmi lainnya. Seluruh data teks tersebut disalin dan disusun di dalam perangkat lunak *Microsoft Excel*, kemudian melalui tahap validasi oleh dokter umum selaku pakar medis. Berdasarkan hasil validasi pakar, diperoleh data akhir pada lembar kerja *Excel* dengan 148 data masuk ke dalam kelas Fakta dan 52 data masuk ke dalam kelas Mitos. Sampel data yang telah divalidasi ini disajikan pada Tabel 1.

Tabel 1. Sampel Data Tervalidasi

Data Teks	Label
Menempelkan es batu pada luka bakar, justru bisa merusak jaringan kulit.	Fakta
Katanya, tidur dengan rambut basah bisa menyebabkan pilek.	Mitos
Alasannya, suhu dingin dari es batu dipercaya bisa membuat luka membaik.	Mitos

2. Text Preprocessing

Setelah data teks kesehatan selesai divalidasi oleh pakar medis, seluruh data teks masuk ke dalam tahap prapemrosesan. Proses ini dijalankan secara berurutan menggunakan bahasa pemrograman *Python 3.10* dengan memanfaatkan beberapa *library*. *Library Pandas* digunakan di awal untuk membaca data dari format *Excel* ke dalam struktur *DataFrame*. Proses pembersihan teks dimulai dengan tahap *case folding* menggunakan metode bawaan *Python* yaitu *.lower()*. Selanjutnya, *cleaning symbol* menggunakan *library re (Regex)*. Setelah teks bersih dari simbol, dilanjutkan tahap *tokenization* menggunakan metode bawaan *.split()*. Untuk proses *stopwords removal*, menggunakan fungsi dari *StopWordRemoverFactory*. Tahap prapemrosesan diakhiri dengan proses *stemming* menggunakan fungsi *StemmerFactory* dari *library Sastrawi*. Sampel data hasil transformasi disajikan pada Tabel 2.

Tabel 2. Sampel Data Hasil Tahapan Prapemrosesan Teks Kesehatan

No	Sebelum Text Preprocessing	Setelah Text Preprocessing
1.	Menempelkan es batu pada luka bakar, justru bisa merusak jaringan kulit.	['tempel', 'es', 'batu', 'luka', 'bakar', 'rusak', 'jaring', 'kulit']
2.	Katanya, tidur dengan rambut basah bisa menyebabkan pilek.	['kata', 'tidur', 'rambut', 'basah', 'sebab', 'pilek']
3.	Alasannya, suhu dingin dari es batu dipercaya bisa membuat luka membaik.	['alasan', 'suhu', 'dingin', 'es', 'batu', 'percaya', 'buat', 'luka', 'baik']

3. Ekstraksi Fitur TF-IDF

Kumpulan kata hasil tahapan prapemrosesan, selanjutnya dikonversi menjadi numerik menggunakan fungsi *TfidfVectorizer* dari pustaka *Scikit-Learn*. Proses pembobotan tersebut menghasilkan matriks data berupa 708 atribut dari 200 data. Sampel hasil urutan bobot total nilai TF-IDF untuk setiap kata disajikan pada Gambar 3 di bawah ini.

term	# rank
sehat	8.023896091498914
makan	6.292985458292506
sebab	6.118927132679474
tubuh	5.428310305254009
orang	5.305145741006461
bantu	5.035469194080641
konsumsi	4.900834700348594
lebih	4.82596443129204
tingkat	4.811560569674508
kurang	4.3859001316036155
risiko	4.305822520815863
kulit	4.033863179748898

Gambar 3. Sampel Data yang Telah Diberi Bobot Tiap Kata

4. Pemodelan dan Pengujian

Proses pemodelan dijalankan untuk melatih model dalam mengenali kalimat mitos dan fakta kesehatan. Sebelum model dilatih, matriks fitur data terlebih dahulu dibagi menjadi data latih dan data uji menggunakan fungsi *train_test_split* dari *library sklearn.model_selection*. Proporsi pembagian ini dilakukan dari 50:50 hingga 90:10 untuk mengetahui rasio data mana yang mendapat hasil tertinggi. Proses klasifikasi dijalankan menggunakan algoritma *RandomForestClassifier* yang diimpor dari *library sklearn.ensemble*. Untuk menangani masalah ketidakseimbangan data dari 200 data (148 Fakta dan 52 Mitos), parameter *weighting* berupa *class_weight='balanced'* digunakan. Hasil pengujian rasio data pada pemodelan ini disajikan pada Tabel 3.


Tabel 3. Hasil Pengujian Model Berdasarkan Rasio Data

No.	Rasio Data	Accuracy	Precision	Recall	F1-Score
1.	50:50	0.7900	0.7710	0.7900	0.7757
2.	60:40	0.7625	0.7400	0.7625	0.7479
3.	70:30	0.7667	0.7372	0.7667	0.7338
4.	80:20	0.7750	0.7664	0.7750	0.7702
5.	90:10	0.8500	0.8438	0.8500	0.8441

Pada Tabel 4 di atas dapat dilihat bahwa pembagian dengan rasio data 90% data *training* (180 data) dan 10% data *testing* (20 data) mendapat hasil terbaik, yakni mendapat akurasi sebesar 85%, presisi sebesar 84,38%, *recall* sebesar 85%, dan f1-score 84,41%.

5. Evaluasi Performa

Tahap akhir adalah mengevaluasi performa dari model *Random Forest*. Proses kalkulasi nilai metrik performa secara keseluruhan dihitung memanfaatkan fungsi *accuracy_score*, *precision_score*, *recall_score*, dan *f1_score* dari *library sklearn.metrics*. Evaluasi performa yang membagi per kelas dilakukan menggunakan fungsi *classification_report*. Sebelum melihat hasil angka metrik keseluruhan, jumlah tebakan benar dan salah dari model divisualisasikan terlebih dahulu menggunakan fungsi *confusion_matrix* dan *ConfusionMatrixDisplay*. Hasil visualisasi pada rasio data 90:10 ditampilkan menggunakan *library matplotlib.pyplot* yang ditunjukkan pada Gambar 4.



Gambar 4. *Confusion Matrix Display*

Berdasarkan Gambar 4 disajikan sebaran hasil prediksi model terhadap 20 data uji dengan rincian *True Positive* (TP), sebanyak 3 data Mitos berhasil ditebak dengan benar oleh sistem. *False Positive* (FP), sebanyak 2 data yang aslinya Mitos salah ditebak menjadi Fakta oleh sistem. *False Negative* (FN), sebanyak 1 data yang aslinya Fakta salah ditebak menjadi Mitos oleh sistem. *True Positive* (TP), sebanyak 14 data Fakta berhasil ditebak dengan benar oleh sistem. Dari sebaran nilai TN, FP, FN, dan TP pada Gambar 4, detail performa per kelas disajikan menggunakan fungsi *classification_report* dan disajikan secara pada Gambar 5.

	precision	recall	f1-score	support
Mitos	0.7500	0.6000	0.6667	5
Fakta	0.8750	0.9333	0.9032	15
accuracy			0.8500	20
macro avg	0.8125	0.7667	0.7849	20
weighted avg	0.8438	0.8500	0.8441	20

Gambar 5. Laporan Evaluasi Per Kelas

Berdasarkan hasil pada Gambar 5, model *Random Forest* mendapat nilai akurasi keseluruhan sebesar 0.8500. Nilai *weighted average* untuk presisi adalah 0.8438, *recall* sebesar 0.8500, dan *f1-score* sebesar 0.8441. Jika dianalisis pada masing-masing kelas, terdapat perbedaan performa yang dipengaruhi oleh jumlah sampel data uji (*support*). Pada kelas Fakta, model menghasilkan performa yang tinggi dengan *precision* 0.8750, *recall* 0.9333, dan *f1-score* 0.9032. Nilai ini didasarkan pada tingginya nilai TP dengan 14 data dibandingkan nilai FN yang hanya 1 data. Sedangkan pada kelas Mitos, model menghasilkan *precision* sebesar 0.7500, namun nilai *recall* turun ke angka 0.6000 sehingga nilai *f1-score* menjadi 0.6667. Nilai *recall* 0.6000 ini terjadi karena nilai TN hanya berjumlah 3 data, sementara nilai FP mencapai 2 data.

Kondisi turunnya nilai *recall* pada kelas Mitos disebabkan oleh dampak ketidakseimbangan data. Meskipun parameter *class_weight='balanced'* sudah digunakan untuk menyeimbangkan bobot saat proses latihan model, jumlah sampel kalimat Mitos yang sedikit tetap membuat belajarnya model menjadi lebih terbatas dibandingkan kelas Fakta. Namun, hasil klasifikasi untuk kelas minoritas ini tetap valid. Berdasarkan teori evaluasi klasifikasi dua kelas oleh David dan Ailab, nilai *f1-score* sebesar 0,5000 merupakan ambang batas bawah yang menunjukkan performa tebakan acak (*chance-level baseline*) [19]. Nilai *f1-score* kelas Mitos pada penelitian ini mencapai angka 0,6667. Karena angka tersebut berada di atas nilai 0,5000, hal ini menunjukkan bahwa model *Random Forest* dengan *class_weight='balanced'* bekerja berdasarkan hasil mempelajari pola teks data, bukan hasil

tebakan acak di tengah kondisi *dataset* yang tidak seimbang dan terbukti mampu menjaga performa klasifikasi kelas minoritas tetap berada di atas ambang batas.

IV. KESIMPULAN

Penelitian klasifikasi teks mitos dan fakta kesehatan menggunakan algoritma *Random Forest* serta optimasi parameter *class_weight='balanced'*, pada rasio data 90:10 menghasilkan metrik evaluasi yang terukur. Hasil pengujian terhadap data uji menunjukkan nilai akurasi keseluruhan sebesar 85,00%, dengan *weighted average* untuk presisi sebesar 0.8438, *recall* sebesar 0.8500, dan *f1-score* sebesar 0.8441. Berdasarkan grafik *Confusion Matrix*, model berhasil memprediksi 3 data TN dan 14 data TP, meskipun masih terdapat kesalahan klasifikasi berupa 2 data FP dan 1 data FN. Dampak ketidakseimbangan *dataset* memengaruhi performa per kelas, di mana kelas Fakta mendapatkan nilai *f1-score* yang lebih tinggi yaitu 0.9032, sedangkan kelas Mitos menghasilkan *f1-score* sebesar 0.6667. Namun demikian, hasil pengujian ini memberikan kontribusi ilmiah berupa pembuktian bahwa penerapan parameter *class_weight* terbukti mampu mempertahankan nilai *f1-score* kelas minoritas berada di atas ambang batas bawah tebakan acak sebesar 0,5000 berdasarkan teori David dan Ailab, sehingga analisis performa model ini dapat menjadi acuan yang valid dalam pengembangan pemodelan klasifikasi hoaks kesehatan ke depan. Saran untuk penelitian selanjutnya adalah menambah volume sampel data teks pada kelas minoritas untuk memperluas ruang *preprocessing* dan fase latihan model. Selain itu, pengujian berikutnya dapat menggunakan metode ekstraksi fitur berbasis konteks makna kalimat guna mengatasi keterbatasan pembobotan kata pada TF-IDF saat memproses kata-kata umum yang sering muncul di kedua kelas data tersebut.

UCAPAN TERIMAKASIH

Penulis menyampaikan apresiasi dan terima kasih yang mendalam kepada dr. Puppy Nawangwulan atas kesediaan waktu, bimbingan, serta kontribusinya sebagai validator data medis dalam penelitian ini. Validasi kepakaran yang diberikan sangat berperan penting dalam menjamin mutu, akurasi, dan kredibilitas informasi kesehatan yang menjadi basis data utama dalam kajian ini.

DAFTAR PUSTAKA

- [1] D. Salihu, F. Abuadas, M. Alanaz, M. Dhiabat, A. Alkhadam, and H. Obiedallah, "Digital Health Literacy, Technology Services and Health Equity in Developing Economies - Concept, Challenges and Recommendations," *Majmaah Journal of Health Sciences*, vol. 13, no. 4, p. 210, 2025, doi: 10.5455/mjhs.2025.04.015.
- [2] M. O. Gallardo and R. Ebarido, "Online Health Information Seeking in Social Media," 2024, pp. 168–179. doi: 10.1007/978-3-031-53731-8_14.
- [3] P. G. G. Wahyu, I. Setiawan, and R. I. Saputri, "Gambaran Perilaku Masyarakat Dalam Mencari Informasi Kesehatan Melalui Internet (Studi pada Kecamatan Pasirjambu, Kabupaten Bandung)," *Padjadjaran Journal of Dental Researchers and Students*, vol. 7, no. 1, p. 81, Mar. 2023, doi: 10.24198/pjdrs.v7i1.40474.
- [4] K. Johnson-Arbor, "I Read Health Information Online—Can I Trust It?," *JAMA Intern. Med.*, vol. 184, no. 9, p. 1138, Sep. 2024, doi: 10.1001/jamainternmed.2024.0340.

- [5] M. M. Ferreira Caceres *et al.*, “The impact of misinformation on the COVID-19 pandemic,” *AIMS Public Health*, vol. 9, no. 2, pp. 262–277, 2022, doi: 10.3934/publichealth.2022018.
- [6] L. S. Martinez, “Health Misinformation and Rumors,” in *The International Encyclopedia of Health Communication*, Wiley, 2022, pp. 1–6. doi: 10.1002/9781119678816.ieh0950.
- [7] T. Diwantara, S. Harini, and M. Imamudin, “ANALISIS PERBANDINGAN ALGORITMA MACHINE LEARNING UNTUK KLASIFIKASI TUTUPAN LAHAN DI KABUPATEN BANJAR,” *Technologia : Jurnal Ilmiah*, vol. 16, no. 4, pp. 841–848, Oct. 2025, doi: 10.31602/TJI.V16I4.20683.
- [8] I. A. Ropikoh, R. Abdulhakim, U. Enri, and N. Sulistiyowati, “Penerapan Algoritma Support Vector Machine (SVM) untuk Klasifikasi Berita Hoax Covid-19,” *Journal of Applied Informatics and Computing*, vol. 5, no. 1, pp. 64–73, Jul. 2021, doi: 10.30871/JAIC.V5I1.3167.
- [9] T. A. Roshinta, E. Kumala, and I. V. Dinata, “Sistem Deteksi Berita Hoax Berbahasa Indonesia Bidang Kesehatan,” *REMIK: Riset dan E-Jurnal Manajemen Informatika Komputer*, vol. 7, no. 2, pp. 1167–1173, Apr. 2023, doi: 10.33395/REMIK.V7I2.12369.
- [10] M. D. Hendriyanto and B. N. Sari, “PENERAPAN ALGORITMA K-NEAREST NEIGHBOR DALAM KLASIFIKASI JUDUL BERITA HOAX,” *JURNAL ILMIAH INFORMATIKA*, vol. 10, no. 02, pp. 80–84, Sep. 2022, doi: 10.33884/JIF.V10I02.5477.
- [11] M. U. Shalih and T. E. E. Tju, “Pembangunan Fitur dalam Identifikasi Cerdas Hoaks dengan Naive Bayes dan Klasifikasi Decision Tree,” *Jutisi : Jurnal Ilmiah Teknik Informatika dan Sistem Informasi*, vol. 13, no. 1, pp. 142–156, Apr. 2024, doi: 10.35889/JUTISI.V13I1.1731.
- [12] R. D. Setyadin, R. H. Winasis, and G. Triyono, “Fake News Detection using the Random Forest Algorithm,” *SISTEMASI*, vol. 14, no. 3, pp. 1142–1153, May 2025, doi: 10.32520/STMSI.V14I3.4995.
- [13] M. Salmi, D. Atif, D. Oliva, A. Abraham, and S. Ventura, “Handling imbalanced medical datasets: review of a decade of research,” *Artificial Intelligence Review 2024 57:10*, vol. 57, no. 10, pp. 273–, Sep. 2024, doi: 10.1007/S10462-024-10884-2.
- [14] J. U. Kazi, “Natural Language Processing (NLP) Basics,” in *Python Essentials for Biomedical Data Analysis: An Introductory Textbook*, Cham: Springer Nature Switzerland, 2025, pp. 463–505. doi: 10.1007/978-3-031-85600-6_12.
- [15] P. K. Reshma, S. Rajagopal, and V. L. Lajish, “A Novel Document and Query Similarity Indexing using VSM for Unstructured Documents,” in *2020 6th International Conference on Advanced Computing and Communication Systems (ICACCS)*, IEEE, Mar. 2020, pp. 676–681. doi: 10.1109/ICACCS48705.2020.9074255.
- [16] Z. Sun, G. Wang, P. Li, H. Wang, M. Zhang, and X. Liang, “An improved random forest based on the classification accuracy and correlation measurement of decision trees,” *Expert Syst. Appl.*, vol. 237, p. 121549, Mar. 2024, doi: 10.1016/J.ESWA.2023.121549.
- [17] H. A. Program *et al.*, “Kajian Performa Metode Class Weight Random Forest pada Klasifikasi Imbalance Data Kelas Curah Hujan,” *Jurnal Sains, Nalar, dan Aplikasi Teknologi Informasi*, vol. 3, no. 1, pp. 42–49, Aug. 2023, doi: 10.20885/SNATI.V3I1.30.
- [18] E. Helmud, Fitriyani, and P. Romadiana, “Classification Comparison Performance of Supervised Machine Learning Random Forest and Decision Tree Algorithms Using Confusion Matrix,” *Jurnal Sisfokom (Sistem Informasi dan Komputer)*, vol. 13, no. 1, pp. 92–97, Feb. 2024, doi: 10.32736/SISFOKOM.V13I1.1985.
- [19] D. M. W. Powers and Ailab, “Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation,” Oct. 2020, Accessed: Jun. 12, 2026. [Online]. Available: <https://arxiv.org/pdf/2010.16061>